

Original Article

<https://doi.org/10.12985/ksaa.2024.32.3.015>
ISSN 1225-9705(print) ISSN 2466-1791(online)

기계학습을 활용한 공항 활주로 지상 바람의 예측

이승민*, 이승재**, 강하림***, 함숙정***, 송재익***, 김기남***

Prediction of Near-Surface Winds on Airport Runways Using Machine Learning

Seung-Min Lee*, Seung-Jae Lee**, Harim Kang***,
Sook Jung Ham***, Jae Ik Song***, Ki Nam Kim***

ABSTRACT

Wind forecast is one of the key meteorological factors required for safe aircraft takeoff and landing. In this study, we developed an artificial intelligence-based wind compensation method by learning the Korea Air Force Weather Research and Forecast (KAF-WRF) forecast data and the Airfield Meteorological Observation System (AMOS) data at five airports using Support Vector Machine (SVM). The SVM wind prediction models were composed of three types according to the learning period (30 days, 40 days, and 60 days) using seven KAF-WRF variables as training data, and the wind prediction performance at the five airports was evaluated using Root Mean Squared Errors (RMSE). According to the results, the SVM wind prediction model trained using U (east-west) and V (north-south) components performed approximately 18% better than the model trained using wind speed and wind direction. The wind correction of KAF-WRF with AMOS observations via SVM outperformed the conventional KAF-WRF wind predictions in eight out of ten cases, capturing abrupt changes in wind direction and speed with a 25% reduction in RMSE.

Key Words : Wind Prediction(바람예측), Machine Learning(기계학습), Support Vector Machine (서포트벡터머신), KAF-WRF(공군수치예보모델), AMOS(공항기상관측장비), Airport Runway Wind(공항활주로바람)

1. 서 론

항공기 이착륙은 항공기 운항 전 과정 중 가장 중요한 과정으로 여겨진다. 특히, 항공기 이착륙은 가장 지

면과 가까운 상태에 있기 때문에 작은 영향에도 큰 사고로 이어질 수 있다. 이러한 항공기 이착륙의 위험성은 바람, 기온, 안개 등과 같은 기상 요소에 의해 극대화될 수 있다. 항공기가 영향을 받는 가장 위험한 기상 요소 중 하나는 풍속과 풍향 등 바람으로 여겨진다(Chaloulos and Lygeros, 2007). 일반적으로 항공기의 양력(lifting force)을 발생시키는 대기속도(air speed)는 항공기의 대지속도(ground speed)와 풍속의 합으로 계산된다(Kim, 2021). 항공기 머리를 기준으로 정면에서 부는 바람인 정풍(headwind)은 이륙 시에는 양력을 발생시켜 단시간에 이륙속도에 도달하

Received: 13. May. 2024, Revised: 20. May. 2024,

Accepted: 30. May. 2024

* 국가농림기상센터 연구개발부 연구원

** 국가농림기상센터 연구개발부 수석연구원

*** 공군기상단

연락처자 E-mail : sjlee@ncam.kr

연락처자 주소 : 서울특별시 관악구 관악로1, 서울대학교

36동 109호

게 하고, 착륙 시에는 속도를 감소시켜 지면충격 감소와 활주거리가 짧아지는 효과가 있다. 이런 측면에서 볼 때, 정풍은 항공기의 이착륙 시 긍정적인 영향을 미쳐서 위험성이 낮다. 배풍(tailwind)은 항공기 후미에서 부는 바람으로, 이착륙에 필요한 활주거리가 늘어나게 되어 정풍과는 반대 효과를 가진다. 측풍(cross-wind)은 항공기 측면에서 부는 바람으로 항공기 이착륙에서 발생하는 바람 중 가장 위험하다고 여겨진다. 측풍은 항공기의 균형을 무너뜨릴 뿐만 아니라, 전복시킬 가능성도 있어서 항공기 이착륙 시 중요하게 고려해야 한다.

항공기 이착륙 사고를 방지하기 위해선 바람을 사전에 예측할 수 있는 예보기술이 중요하다. 바람 예보기술에는 물리적 방법, 통계적 방법, 인공지능 방법이 사용되어 왔다. 물리적 방법은 수치예보모델을 통한 바람예보를 의미한다. 가령, El-Fouly et al. (2006), Lei et al. (2009), Santhosh et al. (2020)은 24시간 이상의 단중기 예측 연구를 수행하였다. 수치예보모델은 온도, 기압, 바람, 습도 등과 같은 기상요소와 지형, 토지 피복 등과 같은 지리적 요인을 종합적으로 고려하여 복잡한 수학적 모델을 구축한다(Wu et al., 2022). 물리적 방법은 바람 예측을 본질적으로 접근하여 계산할 수 있지만, 매우 많은 양의 격자 데이터를 처리하고, 복잡한 비선형 수식의 계산을 수행해야 한다. 따라서 수치예보는 높은 정밀도의 모델을 고안할수록 더 높은 연산 성능을 가진 컴퓨터를 요구하게 된다(Kalnay, 2003). 한편, 통계적 방법은 물리적 방법에서 요구되는 연산 부하량을 대폭 줄이면서 일정 수준의 예측 성능을 보장하고, 과거의 시계열 데이터를 활용하여 예측을 수행하는 방법으로 ARIMA 기반의 회귀모델과 기계학습의 기초적인 형태가 제시되었다(Shukur and Lee, 2015; Lydia et al., 2016; Jeong and Lee, 2018; Singh and Mohapatra, 2019). 인공지능 방법은 기계학습과 딥러닝과 같은 알고리즘을 활용하여 바람 예보를 수행한다. Support Vector Machine(SVM)과 같은 기계학습은 과거의 시계열 데이터를 학습하여 미래의 바람을 예측하는 경우(Fattaheian Dehkordi et al., 2014; Ali et al., 2018; Kwon et al., 2021)와 시계열 데이터 격자점에 위치한 관측자료를 통해 보정하는 경우(Shin et al., 2022)가 있다. 딥러닝 방법은 심층 신경망을 통해 바람의 비선형적인 특징을 학습하기에 적합하다. 인공지능 방법의 등장으로 바람 예보는 고도화되

고 있으며, 기존 물리적 방법, 통계적 방법들과 결합한 하이브리드 모델들도 제시되고 있다(Hu et al., 2016; Araya et al., 2019; Yin et al., 2019; Xu et al., 2021).

바람 예보에 관한 선행연구들은 주로 풍력 발전량과 같은 에너지 자원 분야에 응용하는 경우가 많다(Jung and Broadwater, 2014; Santhosh et al., 2020). 에너지 자원 분야의 바람 예보는 풍속 중심으로 예측하고, 풍향은 보조로 사용되는 경향이 있다. 풍향 예측을 개선하기 위해 일부 연구자들이 통계적인 방법을 제안하기도 하였으나(Bao et al., 2010), 공항 활주로를 대상으로 한 바람보정 연구는 부족한 실정이다. 항공기 이착륙 사고는 풍속은 물론 풍향에도 민감하기 때문에 둘 다를 고려한 바람 예보를 제공해야 한다.

공항 활주로 바람 예보 연구는 윈드시어(wind-shear)로 불리는 급변풍을 대상으로 수행된 사례가 많다(Lee and Kim, 2002; Min et al., 2020; Kim et al., 2021; Kim et al., 2023). 국립기상과학원의 Korea Meteorological Administration Post Processing(KMAPP)은 공항 주변의 고해상도 바람 예측 자료를 생산하고 있으며, 예측 정보의 신뢰도 향상을 위해 지속적인 검증을 수행하고 있다(Seok et al., 2020; Yun et al., 2021; Keum et al., 2021). 특히 KMAPP은 항공기 안전 운항에 영향을 미치는 3,000ft 이하의 저고도 급변풍 예측에 관한 연구도 진행하였다(Seok et al., 2023). 그럼에도 불구하고, 바람은 불규칙하고 불안정한 특성으로 인해 예측이 어려우며, 지속적인 연구개발이 필요하다(Wang et al., 2016).

본 연구에서는 수치예보모델의 바람자료를 기반으로 인공지능 알고리즘을 적용하여 활주로 주변 바람 보정 방법 연구를 수행하였다. 바람 자료는 수치예보모델 자료와 활주로 주변의 관측자료를 사용하였다. 학습모델은 활주로마다 별도로 학습하여 모델을 구축하였으며, 최적의 학습정확도를 나타내는 변수 구성을 사용하였다. 정량적 평가는 학습모델이 적용된 예측자료와 동시간대 관측자료를 비교하여 수행하였다.

II. 자료 및 방법

2.1 공항 지역

Fig. 1은 본 연구의 대상지역들을 Google 위성지도에 나타난 그림이다. 연구 대상지는 해륙풍이 발생하기

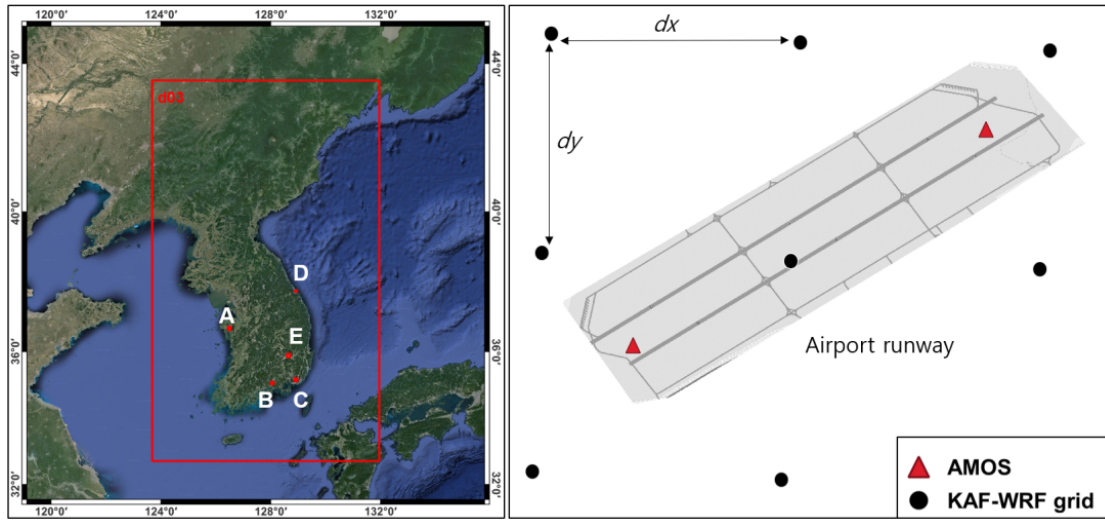


Fig. 1. Wind forecasting experimental area, covering all of South Korea. A-E represents five airport runways in the wind forecast experimental area(A: Seosan, B: Sacheon, C: Gimhae, D: Gangneung, E: Daegu). The figure on the right shows model grid points and AMOS sites around an airport runway

쉬운 서산, 사천, 김해, 강릉(A-D in Fig. 1) 공항과 산곡풍이 발생하기 쉬운 대구(E in Fig. 1) 공항으로 선정하였다. 전 세계적으로 과거에는 공항이 도심지 주변 육지에서 조성됐으나, 도시의 성장과 함께 부동산, 소음 등으로 인해 해안가 근처 바다에 공항을 건설하고 있다(Hyundai E&C, 2024). 해안가에 위치한 공항은 해륙풍의 발생으로 해풍과 육풍간의 전환이 이루어지게 된다(Hwang et al., 2020). 또한, 산지로 둘러싸인 공항은 주변의 지형 특성 상 산곡풍이 발생하여 풍향의 전환이 잦다(An and Kim, 2021).

2.2 활주로 기상 관측자료

인공지능 바람예보 보정은 관측자료를 기반으로 수행하였다. 기상 관측자료는 공항 활주로 주변에 위치한 Aerodrome Meteorological Observation System (AMOS) 자료를 사용하였다. AMOS는 공항 활주로마다 양 끝단에 1개씩 위치하고 있으며, 본 연구에서는 10분 단위 관측자료를 사용하였다(Fig. 1). 인공지능 학습 기간은 평균 풍속이 상대적으로 강했던 기간을 위주로 선정하였다(Table 1). 본 연구에서는 각 기지별로 2가지 사례일을 선정하였으며, Table 2에 요약하였다. 각 공항 활주로는 주변 환경, 지형, 식생, 바다의 위치가 상이하기 때문에 바람의 패턴이 다를 수 있으며, 이를 확인하기 위해 바람장미도를 통해 주풍 분석을 수행하였다.

2.3 수치예보모델 자료

본 연구에서는 인공지능 알고리즘을 활용하여 수치예보모델의 바람 보정을 수행하기 위해 Korea Air-Force-Weather and Research Forecasting(KAF-WRF) 자료를 사용하였다. KAF-WRF는 공군기상단에서 2007년에 구축한 2.1.2버전의 WRF 모델 기반 시스템으로 최근에는 점차 향상되어 3.8.1 버전의 WRF를 기반으로 구성되어 운영 중이다(Byun et al., 2011; Byun et al., 2015). 본 연구에서는 domain 3인 1.3km 공간해상도 자료를 사용하였으며, 1시간 간격으로 24시간 예측을 수행하였다. 예측 기간은 5개 공항의 사례일과 동일한 기간으로 구축하였다. KAF-WRF의 변수 중 U10(10m 동서바람), V10(10m 남북바람), T2(2m 기온), Q2(2m 비습), P(기압), PB(기준기압), PBLH(대기경계층 고도)(Lee et al., 2013), 총 7개 변수를 사용하였다.

2.4 인공지능 바람예측 모델

인공지능 기법을 이용한 바람예측 수행 과정은 Fig. 2와 같다. 온도, 강수량, 풍속과 같은 변수와 달리 풍향은 각도 변수로서 360°와 0°의 수치적 불연속으로 인하여 학습모델의 성능이 저하될 수 있다. 인공지능 바람예측 모델은 사천 공항 활주로를 대상으로 풍속, 풍향을 기반으로 한 변수 구성(SVM ver.1)과 U, V 성

Table 1. AMOS observation data

Airport	Training period (Testing period)	Maximum daily wind speed(m/s)	Type	Runway direction (degree)
Seosan	2022-06-01~2022-06-28 (2022-06-29)	13.5	Coastal	210—030
	2022-08-06~2022-09-05 (2022-09-06)	14.9		
Sacheon	2020-07-01~2020-08-29 (2020-08-30)	9.2	Coastal	240—060
	2023-02-02~2023-03-01 (2023-03-02)	9.8		
Gimhae	2022-06-01~2022-06-28 (2022-06-29)	7.8	Coastal	360—180
	2022-11-23~2022-12-22 (2022-12-23)	5.3		
Gangneung	2022-04-01~2022-05-03 (2022-05-04)	7.4	Coastal	080—260
	2022-09-10~2022-10-09 (2022-10-10)	6.2		
Daegu	2021-01-23~2021-02-21 (2021-02-22)	12.7	Inland	310—130
	2022-08-19~2022-09-18 (2022-09-19)	11.6		

Table 2. Korea Air Force Weather and Research Forecasting(KAF-WRF) specifications

KAF - WRF			
Integration period	AMOS training period		
Domain	d01	d02	d03
Initial condition	NCEP GFS		
Horizontal grid	374 × 316	279 × 423	486 × 867
Spatial resolution (km)	12	4	1.3
Forecast time (hr)	84	84	24
Microphysics	WSM6		
Land surface model	Noah LSM		
PBL scheme	YSU PBL		
Cumulus parameterization	Multi-scale Kain-Fritsch (MSKF)		
Radiation scheme	Rapid Radiative Transfer Model for GCMs (RRTM-G)		

분을 기반으로 한 변수 구성(SVM ver.2)의 성능을 비교하였다. 학습은 2020년 8월 30일 사례를 대상으로 수행하였으며, 학습기간을 60일, 40일, 30일로 나누어 성능의 변화가 발생하는지를 살펴보았다. 각 모델은 AMOS 관측자료의 풍속, 풍향, U, V를 목적 변수로

하며, KAF-WRF를 설명 변수로 사용하였다. 자료의 매칭은 AMOS 관측지점과 가장 가까운 KAF-WRF 격자 중심으로 매칭하였다. 사천 공항을 제외한 4개 공항은 SVM ver.1과 SVM ver.2 중 성능이 뛰어난 변수 구성을 사용하여 학습모델을 구축하였다.

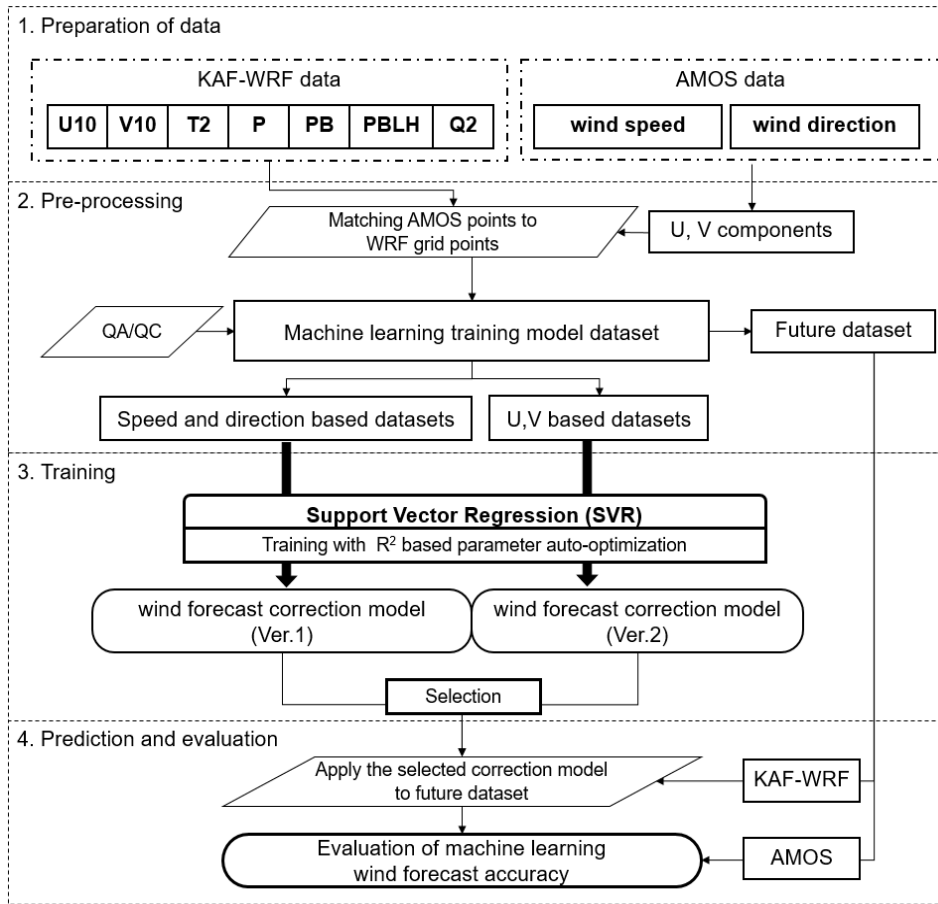


Fig. 2. Flowchart showing the methodology for machine learning based wind correction

인공지능 학습 환경은 Python에서 제공하는 Pycaret 패키지를 사용하였다. Pycaret은 단일 기계 학습을 사용할 때 반복수행을 요구하는 모델 선택, 하이퍼 파라미터 튜닝 등의 작업들을 자동화하는 Auto Machine Learning (AutoML)을 적용한 라이브러리로서 시간 소모적인 과정들을 대폭 줄일 수 있다. 또한, 기존의 Python 개발 환경에서 기계학습을 사용하기 위해 사용되던 Scikit-learn, XGBoost, SpaCy와 같은 라이브러리들을 통합하여 동시에 활용할 수 있다. 기계학습 알고리즘별 매개 변수는 특정한 pipeline을 거치지 않고, K-fold를 통해 가장 높은 R2를 가진 매개변수가 자동으로 선택되도록 수행하였다. 모든 알고리즘은 80%의 training dataset과 20%의 test dataset의 비율을 가지고, 5번의 fold를 거쳐서 최적의 매개 변수를 결정하였다.

인공지능 학습모델은 SVM을 사용하였다. SVM은

입력된 자료에서 각 클래스 자료들간의 거리를 최대로 하는 초평면(hyper plane)을 결정하고, 각 클래스와 거리인 margin이 최대일 때의 직선 support vector를 구하는 분류 알고리즘이다(Cortes and Vapnik, 1995). 이때 생성한 support vector는 예측 모델에서 클래스를 구분하는 경계선이 된다. 이러한 분류 알고리즘은 회귀에 적용하였을 때 Support Vector Regression(SVR)이 된다(Drucker et al., 1996; Smola and Schölkopf, 2004). SVR에서는 margin을 엡실론(ϵ)으로 표현하며, 예측에 적용할 때 ϵ 을 기준으로 입력 자료들을 보정한다. SVR의 기본적인 수식은 식 (1)~(3)과 같다.

$$\text{Hyperplane: } (\vec{w} \cdot \vec{x}) + b = \pm \epsilon \gg w^T x + b = \pm \epsilon \quad (1)$$

$$\text{Min. } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n |\xi_i| \text{ s.t. } y_i(w x_i + b) \leq \pm (|\epsilon| + |\xi_i|) \quad (2)$$

$$y' = \sum_{i=1}^n (a_i - a_i^*) K(x^i, x') + b \quad (3)$$

식 (1)에서 \vec{w} 는 초평면의 중심선에 대해 직교하는 벡터이며, \vec{x} 는 초평면상의 한 점, b 는 절편이다. 두 벡터의 내적은 w 의 전치행렬과 x 의 곱으로 나타낼 수 있다. $w^T x + b = \pm \epsilon$ 는 초평면을 기준으로 두 개의 support vector를 의미하며, 두 벡터 사이의 거리는 $\frac{2}{|w|}$ 이다. 두 support vector 간의 거리를 최대화하기 위해 식 (2)와 같이 $|w|$ 를 최소화 한다. Support vector를 벗어난 자료는 support vector와 자료의 거리를 의미하는 여유변수 ξ 와 비용함수 C 를 추가하여 나타낸다. 이때 제약조건은 자료 y_i 의 거리가 margin 인 ϵ 과 여유변수 ξ 의 합보다 작아야 함을 의미한다. 식 (3)은 학습모델이 구축되었을 때 투입된 자료 x' 에 대한 예측 값 y' 을 나타낸 것이다.

2.5 인공지능 바람예측 성능 평가

바람 예측의 성능 평가는 식 (4)의 Root Mean Square Error(RMSE)를 기반으로 수행하였다. RMSE는 관측값과 예측값을 통해 계산하는 수식이지만, 수치 예보모델의 바람성분은 U, V로 나뉘어져 있어 일반적인 RMSE 수식을 적용하기는 어렵다. 인공지능 바람예측 성능 평가는 U, V성분을 동시에 비교할 수 있도록

$RMSE_{wind}$ 로 응용하여 사용하였다(Rickard et al., 2001; Lee et al., 2011).

$$RMSE_{wind} = \sqrt{\frac{1}{N} \sum_{i=1}^N ((U_{Model} - U_{Obs})_i^2 + (V_{Model} - V_{Obs})_i^2)} \quad (4)$$

식 (4)는 관측값 U_{Obs} , V_{Obs} 와 수치예보모델 격자점들 중 최근접 격자값 U_{Model} , V_{Model} 매칭하여 벡터 제곱근오차를 구하는 것이다. 모든 학습 모델은 한 달간의 학습기간을 기반으로 구축하여 24시간 예측자료에 적용하였기 때문에 N 은 24를 의미한다.

III. 결과 및 고찰

3.1 주풍 분석

Fig. 3은 2020년 7월~2023년 7월에 발생했던 5개 공항 활주로 바람의 특성을 분석한 바람장미도이다. 서산 공항에서는 $190^\circ \sim 240^\circ$ 사이의 남서풍과 $20^\circ \sim 60^\circ$ 사이의 북동풍이 주로 발생하였고, 남서풍 계열이 북동풍 계열보다 6 m/s 이상 강풍의 발생 빈도가 상대적으로 더 많았다(최빈풍은 남남서풍).

사천 공항은 $20^\circ \sim 80^\circ$ 사이의 북동풍 계열이 주로 발생하고 있으며, $190^\circ \sim 260^\circ$ 사이의 남서풍 계열도 일부 발생하였다(최빈풍은 북동풍). 김해 공항은 북동풍,

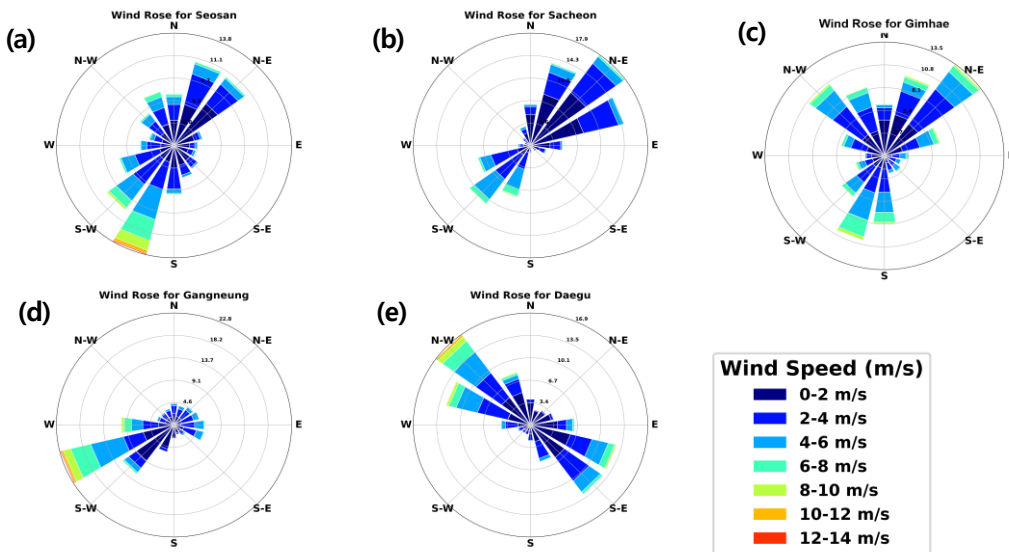


Fig. 3. Windrose diagram for the hourly wind speed and wind direction of AMOS data during the sampled period in July 2020–July 2023. (a) Seosan, (b) Sacheon, (c) Gimhae, (d) Gangneung, (e) Daegu.

북서풍, 남남서풍 등 총 3개의 계열이 빈도 높게 관측되었다(최빈풍은 북동풍). 강릉 공항은 $240^{\circ} \sim 270^{\circ}$ 사이의 서남서풍 계열이 주로 발생하였다. 대구 공항은 $300^{\circ} \sim 340^{\circ}$ 사이의 북서풍 계열과 $100^{\circ} \sim 150^{\circ}$ 사이의 남동풍 계열이 주로 발생하였다.

강릉 공항에서는 주풍인 서남서풍 계열 외에 다른 방향의 바람 빈도는 현저하게 낮으므로, 측풍과 배풍의 위험이 적을 것으로 판단된다. 하지만, 서산, 사천, 대구 공항에서는 주풍과 비슷한 빈도로 역풍이 발생하고 있어 배풍에 의한 위험이 있을 것으로 판단된다. 김해

공항에서는 주풍이 북풍 계열이지만, 범위가 90° 이상이기 때문에 측풍의 위험이 있을 뿐만 아니라, 남풍 계열도 관측되어 배풍의 위험도 있을 것으로 판단된다.

3.2 사천공항에서의 인공지능 바람예측 성능

Fig. 4는 사천 공항에 대한 SVM 예측모델의 결과를 풍향(Fig. 4-a)과 풍속(Fig. 4-b) 시계열 그래프로 나타낸 것이다. Fig. 4-a에서 관측 풍향은 02 UTC에 200° 에서 50° 로 변하고, 05 UTC에 200° 로 변하며, 09 UTC에 다시 50° 로 변하고 10 UTC엔 300° 로 나타났




Fig. 4. Time series graph of the SVM near-surface wind prediction for Sacheon Airport. Wind speed and wind direction based SVM prediction is shown in the SVM ver.1 graph, and U, V based SVM prediction is shown in the SVM ver.2 graph. AMOS observed winds shown as gray dashed lines, and KAF-WRF predicted winds shown as black lines. (a) wind direction. (b) wind speed.

다. 이때 02 UTC~05 UTC 사이의 변화는 SVM ver.1, SVM ver.2 모두 예측하지 못한 것으로 나타났다. 하지만 SVM ver.2는 07 UTC~10 UTC에서 40 일, 30일 학습 자료를 사용하였을 때 풍향의 중요한 전환을 30° 이내의 오차로 예측하여 KAF-WRF보다 성능이 향상된 것으로 나타났다. Fig. 4-b에서 KAF-WRF와 SVM ver.2의 풍속은 01 UTC~11 UTC 사이에 SVM ver.1 모델보다 높은 성능을 나타냈다. KAF-WRF는 11 UTC~16 UTC에 2 m/s 이상의 오차를 보였지만, SVM ver.1, SVM ver.2 모델의 경우, 관측 풍속과 1 m/s 이내의 오차로 예측하여 성능이 향상되었다. 한편, SVM ver.1 풍속은 2 m/s 이하의 풍속만을 예측하여 SVM ver.2나 관측 풍속, KAF-WRF와 비교했을 때 과소모의 하는 경향이 나타났다.

Table 3은 사천 공항의 관측자료를 기준으로 SVM 예측모델의 성능 평가 결과를 나타낸 것이다. SVM ver.1은 학습기간에 따른 RMSE가 60일일 때 1.84, 40일일 때 1.87, 30일일 때 1.89로 소폭 상승하는 결과를 보였다. SVM ver.2는 학습기간에 따른 RMSE가 60일일 때 1.54, 40일일 때 1.46, 30일일 때 1.38로 나타나 학습기간이 짧아질수록 성능이 개선되는 결과를 보였다. SVM 예측모델의 평균 개선율은 SVM ver.1이 10%, SVM ver.2가 28%로 나타나 U·V를 기반으로 학습한 SVM ver.2 모델의 성능이 풍속·풍향을 기반으로 학습한 ver.1 모델보다 성능이 높았다.

3.3 공항별 인공지능 바람예측 성능

본 절에서는 공항 주변 환경에 따른 차이를 비교하기 위해 사천 공항을 제외한 4개 공항에서 각각 2가지 사례

일을 대상으로 SVM ver.2 학습모델을 구축하였다. Fig. 5는 U, V를 기반으로 한 SVM ver.2 예측모델의 학습데이터를 토대로 사천 공항을 제외한 4개 공항의 사례일에 대한 SVM 예측결과를 나타낸 것이다. 서산 공항의 첫 번째 사례일인 2022-06-29에서 풍향에 대한 유의미한 차이를 확인하지 못했으나, 풍속의 개선을 확인하였다. 특히, 11 UTC~15 UTC에는 SVM 예측모델이 KAF-WRF보다 성능이 2 m/s 이상 개선된 것을 확인하였다. 서산 공항의 두 번째 사례일인 2022-09-06은 풍향의 성능 개선을 확인하였다. 16 UTC~18 UTC에 KAF-WRF는 서풍으로 예측했지만, SVM 학습모델은 남동풍으로 관측 풍향과 동일한 방향을 예측하였다.

김해 공항의 첫 번째 사례일인 2022-06-29은 09 UTC~11 UTC에서 SVM 예측모델이 KAF-WRF에 비해 1 m/s 이상 과대모의하는 것으로 나타났다. 두 번째 사례일인 2022-12-23은 00 UTC~10 UTC에서 SVM 예측모델이 KAF-WRF에 비해 4 m/s 이상 과소모의하였다. 김해 공항은 전반적으로 SVM 예측모델이 KAF-WRF보다 성능이 낮았는데, 이는 3.1절의 바람장미도에 나타났듯이, 타지역에 비해 U 성분의 범위가 넓어서 발생한 것으로 판단된다.

강릉 지역의 첫 번째 사례일인 2022-05-04은 10 UTC 이후로 SVM 예측모델이 KAF-WRF에 비해 1 m/s 이상 개선되었음을 확인하였다. 두 번째 사례일인 2022-10-10은 SVM 예측모델이 1 m/s 정도의 개선을 나타냈으나, SVM 예측모델과 KAF-WRF 모두 관측 풍속과 10 m/s 차이를 보여 과소모의한 것으로 나타났다.

대구 지역의 첫 번째 사례일인 2021-02-22은 풍향에서 개선된 것을 확인하였다. 04 UTC~07 UTC에는 KAF-WRF가 남서풍으로, 18 UTC~20 UTC에는

Table 3. SVM wind correction performance in Sacheon airport

Training model	Training period	RMSE _{wind}		Δ RMSE _{wind}	Change rate (%)
		KAF-WRF	SVM		
SVM ver.1	2020-07-01~2020-08-29 (60 days)	2.03	1.84	-0.23	-11
	2020-07-21~2020-08-29 (40 days)		1.87	-0.2	-10
	2020-08-01~2020-08-29 (30 days)		1.89	-0.18	-9
	Average	2.03	1.87	-0.2	-10
SVM ver.2	2020-07-01~2020-08-29 (60 days)	2.03	1.54	-0.45	-24
	2020-07-21~2020-08-29 (40 days)		1.46	-0.65	-28
	2020-08-01~2020-08-29 (30 days)		1.38	-0.68	-32
	Average	2.03	1.46	-0.57	-28

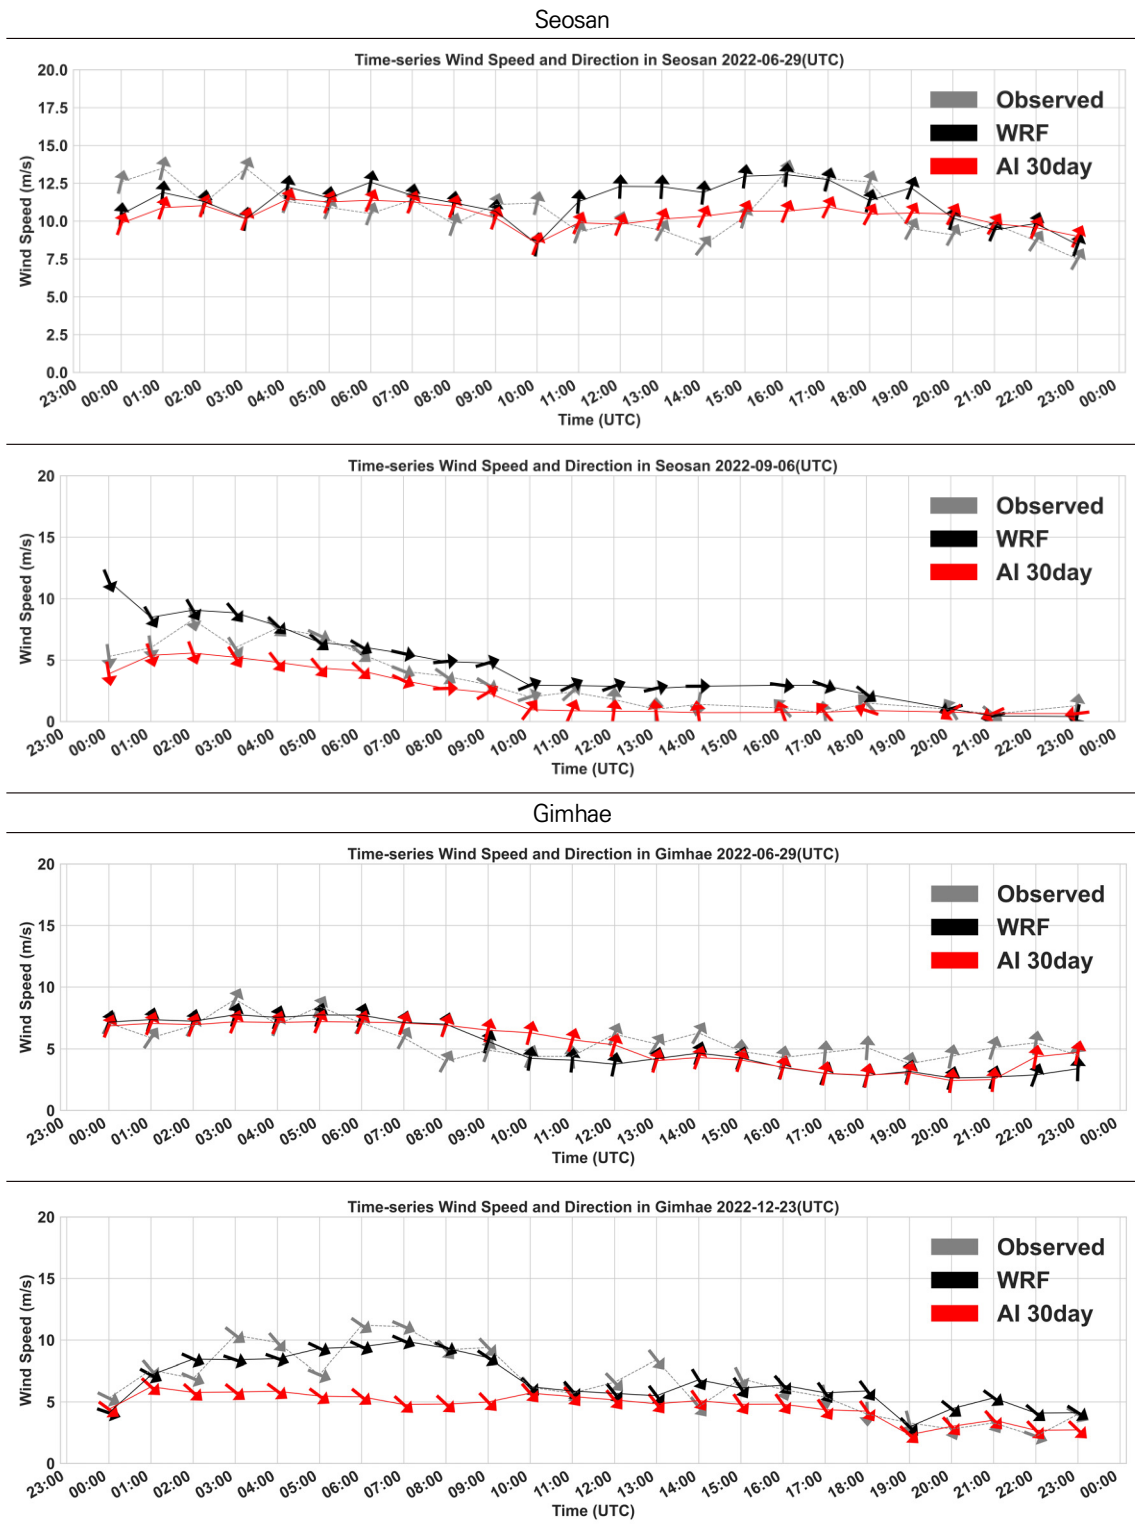




Fig. 5. Time series graph of SVM forecast results for four airports. AMOS winds are shown as gray dashed lines, KAF-WRF winds are shown in black, and SVM predicted winds are shown in red.

Gangneung



Daegu





Fig. 5. Continued

KAF-WRF가 남동풍으로 예측한 데 반해, 관측 풍향과 SVM 예측모델은 두 시간대에서 모두 북서풍으로 나타났다. 대구 지역의 두 번째 사례일인 2022-09-19는 02 UTC~09 UTC 사이에서 KAF-WRF와 관측 풍속에 비해 SVM 예측모델이 4 m/s 이상 과소모의한 것으로 나타났다.

Table 4는 관측자료를 기준으로 SVM 예측모델과 KAF-WRF의 성능을 정량적으로 평가한 결과를 나타낸 것이다. 사천, 강릉, 서산 공항은 모든 사례일에 대해 28% 이상의 개선이 이루어졌다. 김해 공항은 2022-06-29 사례일에서는 KAF-WRF의 RMSE가 1.67, SVM의 RMSE가 1.57로 약 6%의 성능 개선이 이루어졌다. 하지만, 2022-12-23 사례일에서는 KAF-WRF의 RMSE가 2.12, SVM의 RMSE가 2.45로 약 16%의 성능 하락이 발생했다. 대구 공항은 2021-02-22 사례일에서는 42%의 성능 개선이 이루어졌고, 2022-09-19 사례일에서는 2% 성능 하락이 발생했다. 모든 공항의 평균 개선율은 약 25%로 나타나, SVM을 이용한 효과적인 바람 보정이 이루어졌다고 판단된다.

IV. 결 론

본 연구는 5개 공항에서 KAF-WRF 예측결과와 AMOS 활주로 바람 관측자료를 SVM으로 학습하여 인공지능 기반 바람 보정법을 제시하였다. SVM 예측모델은 KAF-WRF의 7종 변수(U10, V10, T2, Q2, P, PB, PBLH)를 학습자료로 이용하고, 학습기간에 따라 60일, 40일, 30일 3가지로 구축하였다. 각 공항의 주

풍을 바람장미도로 분석하고, 풍향·풍속과 $U \cdot V$ 기반의 학습자료를 각각 구축하였다. 5개 공항에서의 바람 예측결과를 RMSE로 평가한 결과, 다음과 같은 결론을 얻었다.

풍향·풍속을 기반으로 학습한 SVM 바람예측모델은 각도 변수의 특성으로 인하여 예측성능이 높지 않아 KAF-WRF 바람보정 모델로 적합하지 않은 것으로 나타났다. 반면에 $U \cdot V$ 를 기반으로 학습한 SVM 바람 예측모델은 풍속과 풍향을 동시에 고려하면서 바람의 전환 시점을 효과적으로 학습하여 KAF-WRF 바람 보정법에 활용 가능한 인공지능 모델로 판단되었다. 전반적으로 SVM 바람예측모델의 성능은 총 10개의 사례 중 8개 사례에서 기존 KAF-WRF보다 우수한 성능을 보여주어 인공지능을 이용한 바람 보정의 효과를 보여주었다. 특히 30일 또는 40일 자료를 $U \cdot V$ 기반으로 학습한 SVM ver.2는 사천 공항 활주로에서 07 UTC~10 UTC에 발생한 중요한 급변 풍향을 30° 이내의 오차로 예측함으로써 KAF-WRF가 놓친 현상을 잘 포착하였다. 한편, 김해, 대구 공항에서는 KAF-WRF의 성능에 미치지 못하는 사례도 있었다. 김해 공항은 다른 공항에 비해 주풍의 범위가 상대적으로 넓고, 해륙풍이 빈번하게 발생하는 것이 그 원인으로 파악되며, 향후 추가적인 개선 연구가 필요하다.

SVM 바람예측모델의 성능은 총 10의 사례 중 8개 사례에서 기존 KAF-WRF보다 우수하였으며, 김해, 대구 공항에서는 기존에 미치지 못하는 사례도 있었다. 특히 김해 공항은 다른 공항에 비해 주풍의 범위가 상대적으로 넓고, 해륙풍이 빈번하게 발생하는 것이 그

Table 4. SVM wind correction performance by airport

Airport	Training period (Test period)	RMSE _{wind}		Δ RMSE _{wind}	Change rate (%)
		KAF-WRF	SVM ver.2		
Sacheon	2020-07-01~2020-08-29 (2020-08-30)	2.03	1.38	-0.65	-32
	2023-02-02~2023-03-01 (2023-03-02)	2.95	1.97	-0.98	-33
Gimhae	2022-06-01~2022-06-28 (2022-06-29)	1.67	1.57	-0.1	-6
	2022-11-23~2022-12-22 (2022-12-23)	2.12	2.45	0.33	16
Daegu	2021-01-23~2021-02-21 (2021-02-22)	5.16	3.00	-2.16	-42
	2022-08-19~2022-09-18 (2022-09-19)	3.09	3.16	0.07	2
Gangneung	2022-04-01~2022-05-03 (2022-05-04)	4.01	2.88	-1.13	-28
	2022-09-10~2022-10-09 (2022-10-10)	6.09	3.65	-2.44	-40
Seosan	2022-06-01~2022-06-28 (2022-06-29)	2.74	1.60	-1.14	-42
	2022-08-06~2022-09-05 (2022-09-06)	2.51	1.52	-0.99	-39
Average		3.24	2.32	0.92	-25

원인으로 파악되며, 추가적인 개선 연구가 필요하다.

SVM 바람예측모델은 지점 기반 모델로서, 관측지가 존재하는 KAF-WRF 격자에서 학습이 되는 모델이기 때문에, 학습기간 안에 예측 사례일과 유사한 바람 패턴이 있다면 예측 성능이 개선되나, 사례일과 같은 바람 패턴이 없다면 예측 성능이 하락될 수 있다는 한계점이 존재한다. 따라서, 인공지능 바람 보정법이 다양한 유형의 바람 패턴을 학습할 수 있도록 공항별 맞춤형 인공지능 예측 모델을 구축할 필요가 있다. 또한, 장기간의 학습자료는 복잡한 형태의 바람들을 포함할 수 있으므로, 딥러닝과 같은 인공지능 알고리즘을 향후 도입하여 지속적으로 유지관리해 나가야 할 것이다.

감사의 글

본 연구는 공군기상단 연구개발 용역사업 '23-F-AI 기반 비행단 맞춤형 바람예보법 적용 연구'의 지원으로 수행되었습니다.

References

1. Chaloulos, G., and Lygeros, J., "Effect of wind correlation on aircraft conflict probability", *Journal of Guidance, Control, and Dynamics*, 30(6), 2007, pp.1742-1752.
2. Kim, S., "The impact of extreme weather events on flight delays & cancellations with a focus on Gimpo-Jeju air route", M.S. Thesis, Seoul National University, Seoul, 2021.
3. El-Fouly, T. H. M., El-Saadany, E. F., and Salama, M. M. A., "One day ahead prediction of wind speed using annual trends", *IEEE Power Engineering Society General Meeting*, 2006, pp.1-7.
4. Lei, M., Shiyang, L., Chuanwen, J., Hongling, L., and Yan, Z., "A review on the forecasting of wind speed and generated power", *Renewable and Sustainable Energy Reviews*, 13(4), 2009, pp.915-920.
5. Santhosh, M., Venkaiah, C., and Vinod Kumar, D. M., "Current advances and approaches in wind speed and wind power forecasting for improved renewable energy integration: A review", *Engineering Reports*, 2(6), 2020, e12178.
6. Wu, Z., Luo, G., Yang, Z., Guo, Y., Li, K., and Xue, Y., "A comprehensive review on deep learning approaches in wind forecasting applications", *CAAI Transactions on Intelligence Technology*, 7(2), 2022, pp.129-143.
7. Kalnay, E., "Atmospheric modeling, data assimilation and predictability", Cambridge University Press, 2003, pp.18-19.
8. Shukur, O. B., and Lee, M. H., "Daily wind speed forecasting through hybrid KF-ANN model based on ARIMA", *Renewable Energy*, 76, 2015, pp.637-647.
9. Lydia, M., Kumar, S. S., Selvakumar, A. I., and Kumar, G. E. P., "Linear and non-linear autoregressive models for short-term wind speed forecasting", *Energy Conversion and Management*, 112, 2016, pp.115-124.
10. Jeong, J., and Lee, S. J., "A statistical parameter correction technique for WRF medium-range prediction of near-surface temperature and wind speed using generalized linear model", *Atmosphere*, 9(8), 2018, pp.291.
11. Singh, S. N., and Mohapatra, A., "Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting", *Renewable Energy*, 136, 2019, pp.758-768.
12. Fattaheian-Dehkordi, S., Fereidunian, A., Gholami-Dehkordi, H., and Lesani, H., "Hour ahead demand forecasting in smart grid using support vector regression (SVR)", *International Transactions on Electrical Energy Systems*, 24(12), 2014, pp.1650-1663.
13. Ali, M., Khan, A., and Rehman, N. U., "Hybrid multiscale wind speed forecasting based on variational mode decomposition", *International Transactions on Electrical Energy Systems*, 28(1), 2018, e2466.
14. Kwon, S. Y., Lee, S. J., and Kim, M. I., "A Statistical correction of point time series data of the NCAM-LAMP medium-range prediction system using support vector ma-

- chine", *Korean Journal of Agricultural and Forest Meteorology*, 23(4), 2021, pp.415-423.
15. Shin, J. Y., Min, B., and Kim, K. R., "High-resolution wind speed forecast system coupling numerical weather prediction and machine learning for agricultural studies—a case study from South Korea", *International Journal of Biometeorology*, 66(7), 2022, pp.1429-1443.
 16. Hu, Q., Zhang, R., and Zhou, Y., "Transfer learning for short-term wind speed prediction with deep neural networks", *Renewable Energy*, 85, 2016, pp.83-95.
 17. Araya, I. A., Valle, C., and Allende, H., "Lstm-based multi-scale model for wind speed forecasting", In *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 23rd Iberoamerican Congress, CIARP 2018, Madrid, Spain, 2019, Proceedings 23*, pp.38-45.
 18. Yin, H., Ou, Z., Huang, S., and Meng, A., "A cascaded deep learning wind power prediction approach based on a two-layer of mode decomposition", *Energy*, 189, 2019, pp.116316.
 19. Xu, W., Liu, P., Cheng, L., Zhou, Y., Xia, Q., Gong, Y., and Liu, Y., "Multi-step wind speed prediction by combining a WRF simulation and an error correction strategy", *Renewable Energy*, 163, 2021, pp.772-782.
 20. Jung, J., and Broadwater, R. P., "Current status and future advances for wind speed and power forecasting", *Renewable and Sustainable Energy Reviews*, 31, 2014, pp.762-777.
 21. Bao, L., Gneiting, T., Gritter, E. P., Guttorp, P., and Raftery, A. E., "Bias correction and Bayesian model averaging for ensemble forecasts of surface wind direction", *Monthly Weather Review*, 138(5), 2010, pp.1811-1821.
 22. Lee, S. J., and Kim, Y. C., "A numerical forecast and verification of the aircraft turbulence observed over South Korea", *Journal of Korean Meteorological Society*, 38(5), 2002, pp.493-507.
 23. Min, B., Kim, Y. H., Choi, H. W., Jeong, H. S., Kim, K. R., and Kim, S., "Low-level wind shear (LLWS) forecasts at Jeju International Airport using the KMAPP", *Atmosphere*, 30(3), 2020, pp.277-291.
 24. Kim, G. H., Choi, H. W., Seok, J. H., and Kim, Y. H., "Prediction of low level wind shear using high resolution numerical weather prediction model at the Jeju International Airport, Korea", *Journal of the Korean Society for Aviation and Aeronautics*, 29(4), 2021, pp.88-95.
 25. Kim, G. H., Choi, H. W., Seok, J. H., Lee, S. S., and Lee Y. H., "Low level wind shear characteristics and predictability at the Jeju International Airport", *Journal of the Korean Society for Aviation and Aeronautics*, 31, 2023, pp.55-58.
 26. Seok, J. H., Choi, H. W., Kim, Y. H. and Lee, S. S., "Diagnosis of low-level aviation turbulence using the Korea meteorological administration post processing (KMAPP)", *Journal of the Korean Society for Aviation and Aeronautics*, 28(4), 2020, pp.1-11.
 27. Yun, J., Kim, Y. H., and Choi, H. W., "Analyses of the meteorological characteristics over South Korea for wind power applications using KMAPP", *Atmosphere*, 31(1), 2021, pp.1-15.
 28. Keum, W. H., Lee, S. H., Lee, D. I., Lee, S. S., and Kim, Y. H., "Evaluation and improvement of the KMAPP surface wind speed prediction over complex terrain areas", *Atmosphere*, 31(1), 2021, pp.85-100.
 29. Seok, J. H., Choi, H. W., Kim, G. H., Lee, S. S., and Lee, Y. H., "Verification of low-level wind shear prediction system using aircraft meteorological data relay (AMDAR)", *Journal of the Korean Society for Aviation and Aeronautics*, 31(3), 2023, pp.59-70.
 30. Wang, J., Song, Y., Liu, F., and Hou, R., "Analysis and application of forecasting models in wind power integration: A review

- of multi-step-ahead wind speed forecasting models", *Renewable and Sustainable Energy Reviews*, 60, 2016, pp.960-981.
31. Hyundai E&C, "Secrets of airports shared by Hyundai E&C's Airport Experts", Hyundai E&C Newsroom, 2024, Available from: https://en.hdec.kr/en/newsroom/news_view.aspx?NewsSeq=780&NewsType=FEATURE&NewsListType=news_clist
 32. Hwang, H., Eun, S. H., Kim, B. G., Park, S. J., and Park, G. M., "Occurrence characteristics of sea breeze in the gangneung region for 2009~2018", *Atmosphere*, 30(3), 2020, pp.221-236.
 33. An, E. J., and Kim, H. D., "Characteristics of mountain and valley winds observed at Palgongsan Mountain and their effects on reducing high temperatures in summer", *Quantitative Bio-Science*, 40(2), 2021, pp.77-82.
 34. Byun, U. Y., Hong, S. Y., Shin, H., Lee, J. W., Song, J. I., Hahm, S. J. Kim, J. K., Kim, H. W., and Kim, J. S., "WRF-based short-range forecast system of the Korea Air Force: Verification of prediction skill in 2009 summer", *Atmosphere*, 21(2), 2011, pp.197-208.
 35. Byun, U. Y., Hong, J., Hong, S. Y., and Shin, H. H., "Numerical simulations of heavy rainfall over central Korea on 21 September 2010 using the WRF model", *Advances in Atmospheric Sciences*, 32, 2015, pp.855-869.
 36. Lee, S. J., Lee, J., Greybush, S. J., Kang, M., and Kim, J., "Spatial and temporal variation in PBL height over the Korean peninsula in the KMA operational regional model", *Advances in Meteorology*, 2013, pp.1-16.
 37. Cortes, C., and Vapnik, V., "Support-vector networks", *Machine Learning*, 20, 1995, pp.273-297.
 38. Drucker, H., Burges, C. J., Kaufman, L., Smola, A., and Vapnik, V., "Support vector regression machines", *Advances in Neural Information Processing Systems*, 1996, pp.9.
 39. Smola, A. J., and Schölkopf, B., "A tutorial on support vector regression", *Statistics and Computing*, 14, 2004, pp.199-222.
 40. Rickard, G. J., Lunnon, R. W., and Tenenbaum, J., "The met office upper air winds: Prediction and verification in the context of commercial aviation data", *Meteorological Applications*, 8(3), 2001, pp.351-360.
 41. Lee, S. J., Parrish, D. F., Park, S. Y., Wu, W. S., Greybush, S. J., Lee, W. J., and Lord, S. J., "Effects of 2-m air temperature assimilation and a new near-surface observation operator on the NCEP Gridpoint Statistical-Interpolation system", *Asia-Pacific Journal of Atmospheric Sciences*, 47, 2011, pp.353-376.